· 70 ·

DOI: 10. 13382/j. jemi. B2205719

基于轻量级密集残差网络的水下图像增强*

周露珊赵磊李恒刘辉张国银

(昆明理工大学信息工程与自动化学院 昆明 650500)

摘 要:深度卷积神经网络是水下图像增强的主要方法之一,但其过高的内存消耗和计算需求阻碍了在实际应用中的部署。为此,提出一种轻量级的密集残差卷积神经网络(dense residual convolutional neural networks, DRCNN)用于水下图像增强。为降低计算成本,DRCNN采用深度可分离卷积提取高级特征;通过密集连接和残差学习促进不同通道之间的信息交互,提高模型表征能力;将输入的退化图像与中间特征图融合,保留图像全局相似性,同时防止模型梯度消失。实验结果证明 DRCNN 能有效提高水下图像质量,较于现有算法,DRCNN 参数量减少了 85%,PSNR、SSIM 值分别提高了 3%、2%,测试速度提高了 3%。DRCNN使用更少的参数实现了更好的性能,利于在低资源设备的实时场景中应用。
 关键词:水下图像增强;轻量级卷积神经网络;深度可分离卷积;密集连接;残差学习
 中图分类号:TP391;TN919.8 文献标识码:A 国家标准学科分类代码: 510.4050

Underwater image enhancement based on lightweight dense residual network

Zhou Lushan Zhao Lei Li Heng Liu Hui Zhang Guoyin

(Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, China)

Abstract: Deep convolutional neural networks are one of the main methods for underwater image enhancement, but their expensive memory consumption and computational requirements hinder their deployment in practical applications. To this end, a lightweight dense residual convolutional neural networks (DRCNN) is proposed for underwater image enhancement. DRCNN uses depthwise separable convolution to extract high-level features to reduce computational cost; promotes information interaction between different channels through dense connection and residual learning, but also improves model representation; and fuses the input degraded image with the intermediate feature map to preserve image global similarity while preventing model gradients from vanishing. The experimental results demonstrate that DRCNN can significantly improve the quality of underwater images. When compared to the existing algorithm, DRCNN parameters are reduced by 85%, PSNR and SSIM values are increased by 3% and 2% respectively, and test speed is improved by 3%. DRCNN achieves better performance with fewer parameters, which is advantageous for real-time applications on low-resource devices. **Keywords**: underwater image enhancement; lightweight convolutional neural network; depthwise separable convolution; dense connection; residual learning

0 引 言

智能水下机器人(autonomous underwater vehicles, AUVs)和遥控航行器(remotely operated vehicles, ROVs)的发展对水下物体检测、水下考古、海底测绘、水下场景分析、海洋物种迁移监测等^[1-3]水下任务产生了重大影

响。AUVs 和 ROVs 要求对水下图像或视频做出实时解 读,以便能够快速感知水下环境,进而采取后续措施。然 而,由于水下环境的特殊性,AUVs 等视觉传感受到光照 不均、能见度低、光的折射和散射以及细小微粒、悬浮物 的极大影响,导致捕获的水下图像质量下降,出现对比度 低、亮度不均匀、细节模糊、颜色失真等问题。这些问题 严重影响了水下视觉任务的应用与发展,因此,水下图像

收稿日期: 2022-08-01 Received Date: 2022-08-01

^{*}基金项目:国家自然科学基金(61863018)、云南省科技厅面上项目(202001AT070038)资助

增强在一系列海洋作业任务中都极为重要。

在过去的几十年里,研究者们提出了许多水下图像 增强方法。传统的水下图像增强方法主要有非物理模型 方法和基于物理模型的方法^[4]。非物理方法通过直接调 整像素值来提高水下图像的视觉效果,如直方图滑动拉 伸^[5]、直方图均衡化^[6-7]、白平衡^[8]和基于融合的方 法^[9-10]等。由于非物理模型方法不考虑物理成像原理, 因此这些方法通常不足以恢复原始场景特征,尤其是颜 色特征。基于物理模型的方法依赖于先验知识和水下场 景信息,通过对光学成像过程进行建模和估计,逆向求解 以恢复退化图像。常用的算法有暗通道先验^[11-12]、自适 应衰减曲线先验^[13]、红通道补偿^[14]等。此类方法在图像 去嗓、去雾、颜色校正方面效果良好,但是场景深度和光 传播系数等信息在实际应用中很难获得,且先验知识在 不同的水下场景中鲁棒性较弱,这将导致后期的估计产 生严重偏差,出现过度增强或增强不足的问题。

对于在复杂水下场景中有实时图像增强需求的计算 机视觉任务,深度学习方法是更好的选择,其强大的学习 能力和表征能力弥补了传统方法的不足,也因此引来了 越来越多研究者的关注。深度学习方法通过学习大量成 对或不成对的数据,对水下图像进行端到端增强,具体又 可分为基于卷积神经网络(convolutional neural network, CNN) 的方法^[15-20] 和基于生成对抗网络(generative adversarial network, GAN)的方法^[21-24]。Li 等^[25]采用白 平衡、直方图均衡化和伽马校正分别对水下图像进行预 处理,将预处理后的图像输入到门控融合的卷积神经网 络中,由该网络学习各个特征信息的权重,最后加权求和 得到输出的清晰图像。Jamadandi 等^[26]将水下图像增强 问题视为风格转换问题,在卷积神经网络中引入小波变 换,准确地重构了退化图像的特征信息。Li 等^[17]结合水 下成像物理模型与水下场景的光学特性,合成多种场景 下的退化数据集用于训练卷积神经网络,实现了清晰图 像的重建。Wang 等^[15]将 RGB 颜色空间和 HSV 颜色空 间集成在一个复杂的卷积神经网络中,构建了一个端到 端的水下图像增强网络。Islam 等^[21]提出一种基于条件 生成对抗网络的水下图像增强模型,通过在大规模数据 集上对抗训练来学习退化图像和清晰图像之间的非线性 映射,有效提高了图像的视觉感知。Chen 等^[27]将特征金 字塔网络作为提取模块去提取多尺度特征,采用有效的 双向交叉连接方式对提取到的特征进行加权融合,同时 引入多维注意力机制,得到通道和空间维度的注意力权 重后再重建特征,实现了对水下图像的有效增强。

随着视觉引导的水下机器人和遥控航行器的发展, 对构建更小、更轻便的神经网络体系结构的需求越来越 高,对模型性能和资源开销之间的权衡逐渐引起人们关 注。然而,大多数研究致力于建立更深层次和更复杂的 网络结构来实现更好的性能,性能的改进是以网络参数 和模型延迟为代价的。复杂的卷积神经网络通常具有庞 大的参数,这使得模型难以训练,并且数十亿次浮点数运 算对 GPU/CPU 的内存要求甚高,不利于在计算机资源 有限的移动设备上部署。

针对上述问题,本文提出一种基于密集残差连接的 轻量级卷积神经网络用于端到端的水下图像增强。该网 络命名为 DRCNN, 由低级特征提取模块、密集残差块和 全局特征融合模块构成。首先由低级特征提取模块提取 退化图像的浅层特征,并将其用于密集残差块的输入:然 后在密集残差块中通过密集连接和残差学习促进特征传 递,实现局部特征重用,有效缓解轻量模型由于网络结构 简单而不能充分学习图像特征的问题:最后通过跳跃连 接将密集残差块的输出特征图与原始输入的退化图像进 行融合,以保持增强后的图像与原始水下图像之间的结 构相似性。考虑到计算成本问题,网络中采用深度可分 离卷积提取高级特征。在公共数据集(enhancement of underwater visual perception, EUVP)上的大量实验结果表 明,DRCNN 能有效改善水下图像色偏问题、增强图像细 节、提高图像对比度和饱和度:同时,与其他先进的深度 学习算法相比, DRCNN 的参数量减少了 85%, 有利于在 低资源设备上部署:图像处理速度达到每张 0.028 s,可 应用于实时增强场景。

基于轻量级密集残差网络的水下图像 增强

本文基于密集残差连接提出了一种轻量级的水下图 像增强网络,该网络是模块化结构,由低级特征提取模 块、3 个输入输出通道数相同的密集残差块以及全局特 征融合模块堆叠而成。为了减少不必要的计算量和防止 特征信息的丢失,网络中不考虑下采样和上采样操作,整 个过程都是在 256×256 的特征图上进行卷积。整体框架 结构如图 1 所示,每个模块的具体构成由如下几节分别 介绍。

1.1 低级特征提取模块

低级特征提取模块由 1 个卷积层和 1 个激活层组成,旨在从退化的水下图像中提取浅层特征,同时保留原始图像的信息。模块的输入图像 $x \in R^{u \times w \times c}$ 是大小为 256×256 的 3 通道图像,经过卷积核尺寸为 3×3 的卷积 层后,生成大小为 256×256 的 64 通道特征图,模块输出可以表示为:

 $I = R(Conv(x); \theta)$ (1) 式中: x 表示输入图像; Conv 表示卷积操作; R 表示激活 函数; θ 是一组与其相关的权重和偏差; $I \in R^{H \times W \times 64}$ 是低



Fig. 1 Overall framework of DRCNN

级特征提取模块的输出。

低级特征提取模块不改变特征图的大小,避免了在 卷积过程中丢失过多的信息,很好地保持了输入图像的 形状和空间特征的真实性。将该模块的输出作为密集残 差块的输入,在堆叠的密集残差块中学习更高级的特征 表示。

1.2 密集残差块

受 DenseNet^[28]的启发,本文设计了密集残差块 (dense residual block, DRB)。DRB 由卷积层、Dropout 层 和激活层构成,详细结构如图 2 所示。DRB 中采用深度 可分离卷积提取特征,在保持模型性能的前提下减少了 大量参数和计算消耗。与标准卷积不同,深度可分离卷 积包括深度卷积和点卷积,分别从通道域和空间域学习 高级特征。具体地,深度卷积使用 64 个 3×3 的单通道卷 积核分别与输入的 64 通道的数据做逐通道卷积运算,得 到 64 个特征图;点卷积采用 64 个 1×1 的卷积核在 64 个 特征图上进行逐点卷积运算,生成新的 64 个特征图。即 便 DRB 中的点卷积没有扩展特征图数量,它也是必不可 少的。深度卷积独立地对输入层的每个通道做卷积运 算,忽视了不同通道在相同空间上的特征信息的关联性, 因而需要点卷积将 64 个通道上的信息进行融合,生成新 的特征图。



为了减小卷积神经网络参数冗余性对模型的影响, 在每组深度卷积和点卷积之后增加了 Dropout 层,在每个 训练批次中以 0.2 的概率随机丢弃隐藏层单元,在避免 模型过拟合的同时也减少了模型参数。Dropout 层之后 是非线性激活层,用于弥补线性模型的不足。

此外,为了促进通道之间的特征传递,增强特征表示,将 DRB 的所有层与输入层进行密集连接。密集连接将大量局部残差信息通过连接操作与其他卷积层的输出进行融合,有效加强特征重用,利于信息交互。与 DenseNet 的融合方式不同,DRB 采用特征向量相加的方式,表达式如下:

$$Z_{i,0} = f_{CDR}(I) + I \tag{2}$$

$$Z_{i,1} = f_{CDR}(Z_{i,0}) + Z_{i,0} + I$$
(3)

式中: $I \ge DRB$ 的输入特征图, $f_{CDR}(\cdot)$ 表示深度可分离 卷积、Dropout 和 ReLU 的组合函数; $Z_{i,0}$ 表示第 $i \land DRB$ 经过第 1 组密集连接的输出; $Z_{i,1}$ 表示第 $i \land DRB$ 最终 输出的特征图, $I \backslash Z_{i,0} \backslash Z_{i,1}$ 具有相同的维度。

1.3 全局特征融合

将原始输入的三通道图像通过跳跃连接与每个 DRB 提取的中间特征图进行按列拼接,实现全局特征融合。 全局特征融合不仅保留了输入图像和全局特征的空间关 系,有利于获得更真实的增强图像,还能有效缓解模型梯 度消失的问题。需要注意的是,全局特征融合采用的融 合方式与 DRB 中的融合方式不同,全局特征融合不考虑 特征图的通道数量,表达式如下:

$$Y_i = H(f_{CR}(Z_{i,1}), x)$$
 (4)
式中: x 是原始输入的水下退化图像, $f_{CR}(\cdot)$ 表示深度可
分离卷积和 ReLU 的组合函数, $H(\cdot)$ 表示 concatenation
级联操作,即将特征图按通道维度进行拼接,则级联操作
前后的维度变化为: $x \in R^{H \times W \times 3}$, $f_{CR}(Z_{i,1}) \in R^{H \times W \times 61}$, $Y_i \in R^{H \times W \times 64}$ 。

为了使 3 个 DRB 的输入层维度一致,在进行拼接之前,采用一个深度可分离卷积将 DRB 输出的 64 通道特征图改为 61 通道,从而自适应地融合不同级别的特征。此外,深度可分离卷积还能进一步提取特征。

1.4 损失函数

为了保持图像的边缘信息,增强图像的纹理相似性, 本文采用均方误差(mean square error, MSE)损失和内容 感知损失来训练模型。均方误差损失也称为 MSE 损失, 是模型输出图像和参考图像之间的平方差均值。MSE 损失对异常值很敏感,能更好地引导模型从全局相似空 间上学习样本映射。MSE 损失可表示为:

$$Loss_{MSE} = \frac{1}{N} \sum_{i=1}^{N} (x_i - y_i)^2$$
(5)

式中:N是每个训练批次的样本数量,x_i表示模型的输出 图像,y_i表示清晰的参考图像。

受文献[29]的启发,本文引入了内容感知损失来增强图像细节和校正图像颜色。将模型输出图像 x_i 和参考图像 y_i 作为预训练网络 VGG-19 的最后一层卷积层的输入,得到两个高级特征表示 $\varphi(x_i),\varphi(y_i)$,内容感知损失即为 $\varphi(x_i)$ 和 $\varphi(y_i)之间距离的均值。内容感知损失可表示为:$

$$Loss_{VGG} = \frac{1}{N} \sum_{i=1}^{N} \| \varphi(y_i) - \varphi(x_i) \|$$
(6)

总损失函数为均方误差损失和内容感知损失的 总和:

$$Loss = Loss_{MSE} + Loss_{VGG} \tag{7}$$

2 实验结果分析

本文方法基于 PyTorch 深度学习框架,使用 Ubuntu-20.04 系统,GPU 型号为 NVIDIA 3090。将 Islam^[21]提供 的 EUVP 数据集用于训练和评估,训练集、验证集和测 试集的划分采用 EUVP 的默认设置,分别是 11 435 个 训练样本、1 270 个验证样本、515 个测试样本。优化器 使用 ADAM,学习率设为 0.000 2,指数衰减因子为 0.7,隐含节点 dropout 率为 0.2,批次大小为 1,训练步 数为 100。

为证明本文方法的有效性,与其他先进的水下图像 增强深度学习类算法(WaterNet^[25]、UWCNN^[17]、UEC²-Net^[15]、Shallow-UWnet^[20])进行比较,并对本文方法进行 定性评估和定量分析。此外,在浮点运算数、模型参数量 和测试时间 3 个方面的实验结果证明了本文方法的优越 性,针对网络结构和损失函数的消融实验进一步证明了 本文方法的有效性。

2.1 主观评价

EUVP 数据集收集了不同场景、水体类型、光照条件下的水下图像数据,其中测试集有 515 张图像,包含颜色失真、低光照和细节模糊等各种真实的水下图像,图 3 展示了不同算法在 EUVP 测试集上的增强效果。由图可见,WaterNet 加剧了色偏的影响,增强后的图像颜色较暗,仍然保留了大部分蓝色背景和绿色背景,导致图像细节模糊。UWCNN 颜色校正效果不理想,引入了明显的红色色偏。UIEC²-Net 能有效去除绿色背景,但是在偏蓝

的图像上颜色校正效果不明显,且产生了不自然的伪影, 在低光照图像上过度增强,导致图像亮度不均匀,出现局 部过亮,局部过暗的现象。Shallow-UWnet 有效去除了蓝 绿色偏,但是增强后的图像饱和度过低,丢失了部分颜色 特征。

相比之下, DRCNN 颜色校正效果理想, 有效去除了 色偏, 增强了图像的纹理细节特征, 提高了图像清晰度。 同时, DRCNN 保持了原始水下图像的真实颜色分布, 在 一定程度上提高了图像的对比度和亮度, 使增强后的水 下图像具有更真实自然的视觉感知。

2.2 客观指标

本文采用峰值信噪比(peak signal to noise ratio, PSNR)、结构相似性(structural similarity index measure, SSIM)和水下彩色图像质量评价指标(underwater color image quality evaluation, UCIQE)对不同算法增强后的图 像进行定量评估^[30-32]。PSNR 和 SSIM 是全参考的图像 质量评估指标,量化了模型的输出图像与对应的参考图 像之间的相似度,其值越高表示输出图像与参考图像越 接近。PSNR 表达式如下,描述的是增强后的图像与参 考图像之间的均方误差(mean squared error, MSE)。

 $PSNR(x,y) = 10lg[255^2/MSE(x,y)]$ (8)

SSIM 基于亮度、对比度和结构相似度来衡量增强后 图像与参考图像两者之间差异,表达式如下:

SSIM
$$(x, y) = \left(\frac{2\mu_x\mu_y + c_1}{\mu_x^2 + \mu_y^2 + c_1}\right) \left(\frac{2\sigma_{xy} + c_2}{\sigma_x^2 + \sigma_y^2 + c_2}\right)$$
(9)

式中: $\mu_x(\mu_y)$ 表示 x(y)的平均值, $\sigma_x^2 (\sigma_y^2)$ 表示 x(y)的方差, σ_{xy} 代表 x 与 y 之间的关联性, c_1 、 c_2 取值为 $c_1 = (255 \times 0.01)^2$, $c_2 = (255 \times 0.03)^{2[31]}$ 。

UCIQE 是专门针对水下图像设计的无参考指标,从 色度、饱和度、对比度 3 个方面对水下图像进行综合评价,其值越高表示图像质量越好,表达式如下:

UCIQE = $c_3 \times \sigma_c + c_4 \times con_l + c_5 \times \mu_s$ (10) 式中: σ_c 是色度的标准偏差, con_l 是对比度, μ_s 是饱和度 的平均值。 c_3, c_4, c_5 是加权系数, 取值为 $c_3 = 0.4680, c_4 = 0.2745, c_5 = 0.2576^{[32]}$ 。

表1是不同算法在所求指标上的平均值,最佳结果 以粗体显示。与其他算法相比,DRCNN在 PSNR、SSIM 指标上获得最高值,说明本文方法增强后的图像在颜色、 结构信息、纹理细节等方面与参考图像更接近,更符合人 眼视觉。UCIQE 值仅次于 UIEC²-Net,无参考指标只考虑 到对比度、色度和饱和度,而没有考虑到伪影等因素,所 以即便 UIEC²-Net 增强后的图像视觉感知效果不是最 好,但其 UCIQE 值依旧最高。



图 3 不同算法在 EUVP 测试集上的处理效果

Fig. 3 Processing effect of different algorithms in test EUVP

表 1 不同算法在测试集 EUVP 上的定量比较 Table 1 Quantitative comparison of different algorithms on test EUVP

Model	PSNR	SSIM	UCIQE
WaterNet	23.412±4.012	0.785 ± 0.074	0.373±0.053
UIEC ² -Net	21.597±3.650	0.784 ± 0.087	0.446±0.035
UWCNN	19.346±3.198	0.701±0.097	0.365 ± 0.047
Shallow-UWnet	26.762±2.978	0.810±0.066	0.398±0.061
DRCNN	27.664±3.095	0.825±0.064	0.424 ± 0.063

表2为DRCNN与其他算法在浮点运算数、模型参数 量、测试时间上的实验结果对比。从表2中可以看出,与 其他算法相比DRCNN参数量最少,并且没有增加推理 时间,在计算成本上更具竞争力,在有限条件下的可部署 性更高,应该场景更广泛。

2.3 消融实验

为验证本文方法中跳跃连接、密集连接以及内容感 知损失的有效性,进行了大量消融实验,实验结果如图 4 所示,分别是原始退化图像、消除跳跃连接的图像、消除 密集连接的图像、消除内容感知损失的图像以及本文方法增强后的图像。表3展示了消融实验在 PSNR、SSIM、 UCIQU 的平均值,最佳结果以粗体显示。

表 2 不同算法的浮点运算数、模型参数量、测试时间的比较

 Table 2
 Comparison of different algorithms on

FLOPs, parameters and test time

Model	FLOPs/G	Parameters/K	Testing per image/s
WaterNet	71.53	1 090. 668	0.063
UIEC ² -Net	26.14	534.962	0.117
UWCNN	2.63	39.972	0.068
Shallow-UWnet	21.67	219.456	0.029
DRCNN	3.14	32. 430	0. 028

从主观感知角度和客观指标方面均能看出,跳跃连 接有效改善了网络性能,虽然以降低 UCIQU 值为代价,

表 3 消融实验的定量比较

Table 3Quantitative comparisonfor the ablation experiment

	PSNR	SSIM	UCIQE
$w/o^{(1)} SK^{(2)}$	10.961±2.21	0.448 ± 0.071	0.505±0.064
w/o DC ⁽³⁾	27.575±2.983	0.821±0.065	0.414±0.066
w∕o Vgg loss	27.305±3.296	0.823±0.064	0.406 ± 0.065
DRCNN	27.664±3.095	0.825±0.064	0.424±0.063

注:1) w/o 表示 without; 2) SK 是 skip connection 缩写; 3) DC 是 dense connection 缩写。

但是在 PSNR、SSIM 方面贡献很大,保持了增强图像与原 始图像的结构相似性。密集连接能够增强图像的纹理细 节特征,提高图像对比度和饱和度。增加内容感知损失 有利于恢复图像的颜色特征,使增强后的图像更接近真 实的无水图像。



图 4 消融实验的定性结果

Fig. 4 Qualitative results of ablation experiments

3 结 论

针对深度卷积神经网络内存需求过高、计算消耗过 大而难以在实际水下作业中部署的问题,本文提出一个 轻量级全卷积神经网络—DRCNN 用于水下图像实时增 强。DRCNN 采用深度可分离卷积设计轻量级模型,构建 输入输出通道一致的密集残差块来减少内存需求。 DRCNN 基于局部残差学习和全局跳跃连接进行特征融 合,通过密集连接的方式促进特征重用,以此来提高水下 图像质量。在 EUVP 数据集上的实验结果表明 DRCNN 性能优于其他深度学习算法,消融实验进一步证明了所 提方法的有效性。此外,DRCNN 的轻量性、高效性和快 速性使其部署更容易,这一优势在低资源的实时增强场 景中更为明显。

在未来的工作中,主要对轻量级网络在水下视频实 时增强领域的扩展和应用进行研究,并尝试在水下机器 人上部署。

参考文献

[1] ZHOU Z, LIU J, YU J Z. A survey of underwater multi-

robot systems [J]. IEEE / CAA Journal of Automatica Sinica, 2021, 9(1): 1-18.

- [2] ISLAM M J, XIA Y, SATTAR J. Fast underwater image enhancement for improved visual perception [J]. IEEE Robotics and Automation Letters, 2020, 5 (2): 3227-3234.
- [3] 王聪,薛晓军,李恒,等.基于颜色校正和改进二维伽 马函数的水下图像增强[J].电子测量与仪器学报, 2021,35(2):171-178.

WANG C, XUE X J, LI H, et al. Underwater image enhancement based on color correction and improved 2D gamma function [J]. Journal of Electronic Measurement and Instrumentation, 2021,35(2):171-178.

- ZHANG W, DONG L L, PAN X, et al. A survey of restoration and enhancement for underwater images [J].
 IEEE Access, 2019, 7: 182259-182279.
- [5] IQBAL K, ODETAYO M, JAMES A, et al. Enhancing the low quality images using unsupervised colour correction method[C]. IEEE International Conference on Systems, Istanbul, Turkey, 2010: 1703-1709.
- ULUTAS G, USTUBIOGLU B. Underwater image enhancement using contrast limited adaptive histogram equalization and layered difference representation [J]. Multimedia Tools and Applications, 2021, 80 (10): 15067-15091.
- [7] HITAM M S, AWALLUDIN E A, YUSSOF W N J H W, et al. Mixture contrast limited adaptive histogram equalization for underwater image enhancement [C]. International Conference on Computer Applications Technology (ICCAT), Sousse, Tunisia, 2013: 1-5.
- [8] YUAN J, CAO W, CAI Z, et al. An underwater image vision enhancement algorithm based on contour bougie morphology [J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 59(10): 8117-8128.
- [9] ANCUTI C, ANCUTI C O, HABER T, et al. Enhancing underwater images and videos by fusion [C]. IEEE Conference on Computer Vision and Pattern Recognition, Providence, RI, USA, 2012: 81-88.
- [10] ANCUTI C O, ANCUTI C, DE VLEESCHOUWER C, et al. Color balance and fusion for underwater image enhancement [J]. IEEE Transactions on Image Processing, 2017, 27(1): 379-393.
- [11] HE K, SUN J, TANG X. Single image haze removal using dark channel prior [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 33(12): 2341-2353.
- [12] DREWS P L J, NASCIMENTO E R, BOTELHO S S C, et al. Underwater depth estimation and image restoration

based on single images [J]. IEEE Computer Graphics and Applications, 2016, 36(2): 24-35.

- [13] LIU K, LIANG Y. Underwater image enhancement method based on adaptive attenuation-curve prior [J].
 Optics Express, 2021, 29(7): 10321-10345.
- [14] GALDRAN A, PARDO D, PICÓN A, et al. Automatic red-channel underwater image restoration [J]. Journal of Visual Communication and Image Representation, 2015, 26: 132-145.
- [15] WANG Y, GUO J, GAO H, et al. UIEC²-Net: CNNbased underwater image enhancement using two color space [J]. Signal Processing: Image Communication, 2021, 96: 116250.
- [16] HOU M, LIU R, FAN X, et al. Joint residual learning for underwater image enhancement [C]. IEEE International Conference on Image Processing (ICIP), Athens, Greece, 2018: 4043-4047.
- [17] LI C Y, ANWAR S, PORIKLI F. Underwater scene prior inspired deep underwater image and video enhancement [J]. Pattern Recognition, 2020, 98: 107038.
- [18] YANG H H, HUANG K C, CHEN W T. LAFFNet: A lightweight adaptive feature fusion network for underwater image enhancement [C]. IEEE International Conference on Robotics and Automation (ICRA), Xi'an, China, 2021: 685-692.
- GANGISETTY S, RAI R R. FloodNet: Underwater image restoration based on residual dense learning [J].
 Signal Processing: Image Communication, 2022, 104: 116647.
- [20] NAIK A, SWARNAKAR A, MITTAL K. Shallow-UWnet: Compressed model for underwater image enhancement (student abstract) [C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(18): 15853-15854.
- [21] ISLAM M J, XIA Y, SATTAR J. Fast underwater image enhancement for improved visual perception [J]. IEEE Robotics and Automation Letters, 2020, 5 (2): 3227-3234.
- [22] FABBRI C, ISLAM M J, SATTAR J. Enhancing underwater imagery using generative adversarial networks [C]. IEEE International Conference on Robotics and Automation (ICRA), Brisbane, QLD, Australia, 2018: 7159-7165.
- [23] LI J, SKINNER K A, EUSTICE R M, et al. WaterGAN: Unsupervised generative network to enable real-time color correction of monocular underwater images [J]. IEEE Robotics and Automation letters, 2017, 3(1): 387-394.
- [24] GUO Y, LI H, ZHUANG P. Underwater image

enhancement using a multiscale dense generative adversarial network [J]. IEEE Journal of Oceanic Engineering, 2019, 45(3): 862-870.

- [25] LI C Y, GUO C, REN W, et al. An underwater image enhancement benchmark dataset and beyond [J]. IEEE Transactions on Image Processing, 2019, 29: 4376-4389.
- [26] JAMADANDI A, MUDENAGUDI U. Exemplar-based underwater image enhancement augmented by wavelet corrected transforms[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, 2019: 11-17.
- [27] CHEN R, CAI Z, CAO W. MFFN: An underwater sensing scene image enhancement method based on multiscale feature fusion network[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 60: 1-12.
- [28] HUANG G, LIU Z, VAN DER MAATER L, et al. Densely connected convolutional networks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 4700-4708.
- [29] JOHNSON J, ALAHI A, LI F F. Perceptual losses for real-time style transfer and super-resolution [C].
 European Conference on Computer Vision. Berlin, Germany: Springer, 2016: 694-711.
- [30] IGNATOV A, KOBYSHEV N, TIMOFTE R, et al. DSLR-quality photos on mobile devices with deep convolutional networks [C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 3277-3285.

- [31] CHEN Y S, WANG Y C, KAO M H, et al. Deep photo enhancer: Unpaired learning for image enhancement from photographs with GANs [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 6306-6314.
- [32] YANG M, SOWMYA A. An underwater color image quality evaluation metric [J]. IEEE Transactions on Image Processing, 2015, 24(12): 6062-6071.

作者简介



周露跚,2020年于昆明理工大学获得 学士学位,现为昆明理工大学的硕士研究 生,主要研究方向为水下图像处理。 E-mail: 18468111430@163.com

Zhou Lushan received her B. Sc. degree from Kunming University of Science and

Technology in 2020. Now she is a M. Sc. candidate at Kunming University of Science and Technology. Her main research interest includes underwater image processing.



赵磊(通信作者),2002 年于昆明理工 大学获得学士学位,2006 年于昆明理工大 学获得硕士学位,现为昆明理工大学实验 师,主要研究方向为图像处理、机器学习。 E-mail: zhaolei@ sohu.com

Zhao Lei (Corresponding author)

received his B. Sc. degree from Kunming University of Science and Technology in 2002, M. Sc. degree from Kunming University of Science and Technology in 2006 respectively. Now he is an experimenter in Kunming University of Science and Technology. His main research interests include image processing and machine learning.